基于改进的 LSTM 复杂控制系统的故障预测

金怀智[1]，张英[2]，陈伟[2]，袁峰[1]

1. 哈尔滨工业大学仪器科学与工程学院，哈尔滨 150001
2. 北京航天自动控制研究所， 北京 100070
E-mail: 516525465@qq.com

摘　要：针对复杂控制系统故障特征提取困难，外部激励影响故障预测准确率等问题，本文以异步电机为研究对象，提出了一种短时傅里叶变换（STFT）和长短时记忆神经网络（LSTM）结合并行卷积神经网络（PCNN）的故障诊断方法。首先，通过短时傅里叶变换（STFT）和长短时记忆神经网络（LSTM）对信号进行降噪处理。其次，采用平均影响值算法（MIV）计算各特征量的重要程度和累计贡献率。最后，建立并行卷积长短时记忆神经网络（PCNN-LSTM）的异步电机故障诊断模型，通过将PCNN的特征提取能力与LSTM的时序信息记忆能力相结合，增强模型的故障预测的性能。实验结果分析表明：本文提出的方法，故障诊断准确率高，具有更好的鲁棒性。

关键词: 长短时记忆神经网络；平均影响值算法；卷积神经网络

Fault prediction of complex control systems based on improved LSTM

Huaizhi JIN[1], Ying ZHANG[2], Wei CHEN[2] ,Feng YUAN[1]

1. School of Instrumentation Science and Engineering, Harbin Institute of Technology, Harbin 15001
2. Beijing Institute of Aerospace Automatic Controls, Beijing 100070
E-mail: 516525465@qq.com

Abstract: In response to the difficulties in extracting fault features from complex control systems and the impact of external stimuli on fault prediction accuracy, this paper takes asynchronous motors as the research object and proposes a fault diagnosis method that combines short-time Fourier transform (STFT) and long short-term memory neural network (LSTM) with parallel convolutional neural network (PCNN). Firstly, the signal is denoised using Short Time Fourier Transform (STFT) and Long Short Term Memory Neural Network (LSTM). Secondly, the Mean Influence Value (MIV) algorithm is used to calculate the importance and cumulative contribution rate of each feature quantity. Finally, a parallel convolutional long short-term memory neural network (PCNN-LSTM) is established for asynchronous motor fault diagnosis. By combining the feature extraction ability of PCNN with the temporal information memory ability of LSTM, the performance of the model's fault prediction is enhanced. The analysis of experimental results shows that the method proposed in this paper has high accuracy in fault diagnosis and better robustness.

Key Words: Long short-term memory neural network, Average Impact Value Algorithm, Convolutional Neural Network

1　引言

复杂控制系统的故障预测是当今研究的热点，异步电机系统又是复杂控制系统的典型之一。虽然目前异步电机的工作可靠性已达到较高水平，但仍可能由于各种原因出现故障。首先，异步电机的工作环境较为复杂，一般利用仪器获取的轴承振动信号会展现出不稳定、含噪量高、非线性的特点。其次，长期的高强度运行和维护的缺乏容易导致异步电机出现故障。此外，异步电机的反复启动和制动等不规范操作可能损害异步电机的机械和电气性能，增大电机出现故障问题的可能性。因此，将完整有效的故障特征从含噪复杂信号中提取出来，采用降噪后的信号进行故障预测，具有十分重要的意义。

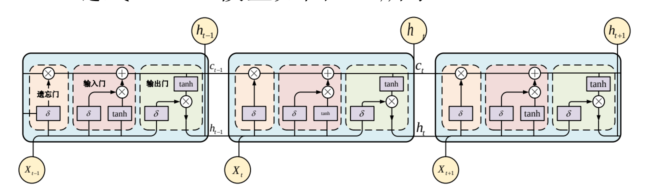
目前，解决外部激励对异步电机的振动信号产生的干扰，常用的降噪方法为经验模态分解[1]（EMD），神经网络降噪等方法。EMD是一种通过检测信号并将其分解为主要模态的方法，该方法可以递归地检测信号中的的局部最大值和最小值，通过对这些极值进行插值来估计下/上包络。然而，经验模态分解会产生模态混叠问题。神经网络降噪是基于深度学习的一种降噪方法。常见的将噪神经网络有DNCNN[2]、LSTM[3]等，DNCNN网络是以卷积神经网络[4](CNN)为基础，通过残差学习的方式对数据降噪；LSTM长短期记忆网络可以从时间序列中学习特征，能够很好的适用于一维信号的降噪处理。对于异步电机故障预测，通常先对异步电机故障数据进行预处理，如小波变换[5]（WT），变分模态分解[6](VMD)等，得到故障特征；然后采用分类算法对故障特征分类，如支持向量机[7]（SVM），人工神经网络等。传统的故障诊断

方法在取得了一些成果，但泛化能力不足，且较依赖于信号处理技术。近些年，随着深度学习方法的提出，开始将卷积神经网络应用于轴承故障诊断中，然而CNN时序信息记忆能力欠缺。针对上述问题，对于异步电机振动信号降噪，本文采用了STFT-LSTM方法。利用LSTM模型对故障数据进行降噪处理，进一步，通过短时傅里叶变换提高LSTM降噪的性能，将经过短时傅里叶变换的故障数据输入LSTM模型进行降噪。对于异步电机的故障预测，本文采用了PCNN-LSTM故障分类模型，PCNN具备强大的特征提取能力，LSTM能够记忆数据的时序特征，避免长期的时序信息在模型训练过程中丢失。通过结合两种神经网络结构的优点，实现更高的故障分类准确率。

2 基于LSTM和MIV法的数据预处理

2.1 LSTM

链式 LSTM 模型如图 2-1 所示，



LSTM 模型中的每个记忆单元包含遗忘门、输入门、输出门三种门控单元，以上图中的第二个记忆单元为例，三种门控单元的工作原理如下：

(1) 遗忘门

LSTM 可以通过遗忘门对上一时刻的输出进行筛选，决定对其进行传递还是遗忘。首先利用神经元 δ 处理上一时刻的输出 h_{t-1} 与当前时刻的输入 X_t，δ 的值会决定 h_{t-1} 的保留程度。经过神经元 δ 处理后的输出值在 0 到 1 之内，输出值越靠近 1 则保留的信息越多，计算公式如式 2-1 所示：

$$f_t = \sigma(W_{if} X_t + b_{if} + W_{hf} h_{t-1} + b_{hf}) \tag{2-1}$$

其中，W_{if} 和 W_{hf} 表示遗忘门的权重，b_{if} 和 b_{hf} 表示遗忘门的偏置。

(2) 输入门与候选值

输入门负责利用当前输入数据更新细胞状态。首先，输入门利用神经元 δ 处理保存在隐节点中上一时刻的输出 h_{t-1} 和当前输入数据 X_t，得到当前时刻的权重值 i_t 与候选值 g_t，如式 2-2、式 2-3 所示。随后将细胞状态 C_{t-1} 更新为 C_t，如式 2-4 所示。

$$i_t = \sigma\left(W_{ii} X_t + b_{ii} + W_{hi} h_{t-1} + b_{hi}\right) \tag{2-2}$$

$$g_t = \sigma\left(W_{ig} X_t + b_{ig} + W_{hg} h_{t-1} + b_{hg}\right) \tag{2-3}$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot g_t \tag{2-4}$$

其中，W_{ii} 与 W_{hi} 表示输入门的权重，W_{ig} 与 W_{hg} 表示候选值的权重；b_{ii} 与 b_{hi} 表示输入门的偏置，b_{ig} 与 b_{hg} 表示输入门的偏置。

(3) 输出门

输出门通过筛选历史数据以计算当前输出值 h_t。首先计算 o_t，随后将 o_t 与经 tanh 层激活后的 C_t 相乘，从而获得当前输出值 h_t。计算过程如式(2-5)、式(2-6)所示。

$$o_t = \sigma\left(W_{io} X_t + b_{i0} + W_{ho} h_{t-1} + b_{ho}\right) \tag{2-5}$$

$$h_t = o_t \cdot \tanh\left(C_t\right) \tag{2-6}$$

其中，W_{io} 与 W_{ho} 表示输出门的权重，b_{io} 与 b_{ho} 表示输出门的偏置。

2.2 平均影响值算法（MIV）

MIV 的符号表示自变量对输出变量具备正影响或负影响，绝对值指示影响程度。MIV 的基本思想是筛选出对神经网络具有重要影响的自变量，排除影响不显著的变量，以实现特征降维的目的。

MIV 算法的主要步骤如下：

(1)每 32 个数据为一组求取降噪后的异步电机故障数据集的均值、方差、峰值、峭度、有效值、峰值因子、脉冲因子、波形因子、裕度因子共九个指标，并添加标签、进行归一化处理，得到训练样本 N。

(2)利用训练样本 N 对神经网络模型进行训练，得到网络模型 Model。

(3)将原样本 N 分别增加和减小 10%得到样本 M1 和 M2。

(4)利用神经网络模型 Model 对样本 M1 和 M2 进行仿真预测，得到预测结果 R1 及 R2。

(5)计算各自变量对输出变量的影响变化值(IV)和平均影响值(MIV)。第 i 个特征指标的第 j 个训练样本的影响变化值为:

$$IV_i^j = M_i^j - N_i^j \tag{2-7}$$

其中，j=1，2，...，m。m 为数据矩阵的行数。第 i 个指标的 MIV 值为：

$$MIV_i = 1/m \times \sum_{m_1}^{m_j} IV_i^j \tag{2-8}$$

(6)根据 MIV 值的绝对值筛选出对输出变量影响程度较大的自变量。

MIV 算法流程图如图 2-2 所示：

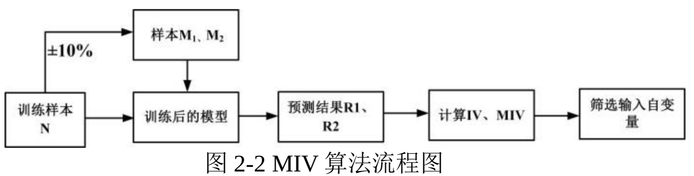


图 2-2 MIV 算法流程图

2.3 STFT-LSTM

通过短时傅里叶变换提高LSTM降噪的性能，选择窗口长度为64，重叠长度为63的短时傅里叶变换，将短时傅里叶变换后的实部和虚部叠加在一起，形成一个输出矩阵。随后将输出矩阵依次输入LSTM模型进行降噪，STFT-LSTM降噪算法流程图如图2-3所示：

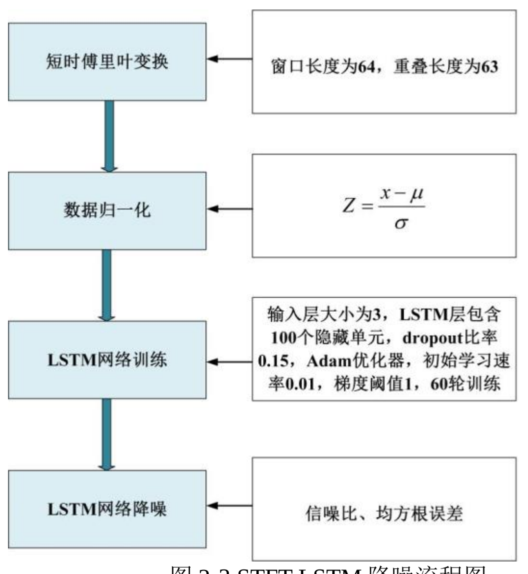


图 2-3 STFT-LSTM 降噪流程图

3.故障诊断方法

3.1 卷积神经网络

卷积神经网络（CNN）是一种前馈神经网络，该方法通过卷积运算来获取数据的特征，即通过滑动滤波器与与原始数据的每一小部分进行卷积运算来得到特征矩阵。该神经网络由独立的计算单元构成，在训练过程中，先通过反向传播得到权重和偏置等参数，在计算的时候将输入和权重点积。卷积神经网络一般包括卷积层、池化层、激活层和全连接层。

3.2 PCNN-LSTM

PCNN-LSTM模型的参数和结构对异步电机故障诊断的准确率和速度具有直接影响，不恰当的参数可能导致模型出现过拟合或欠拟合，降低故障分类准确率，还可能导致训练时间过长。因此，分别构建不同参数和结构的网络模型，通过分类准确率和各评价指标不断优化模型，最终确定了最佳的参数和结构。本文所构建的PCNN-LSTM模型结构如图3-1所示：

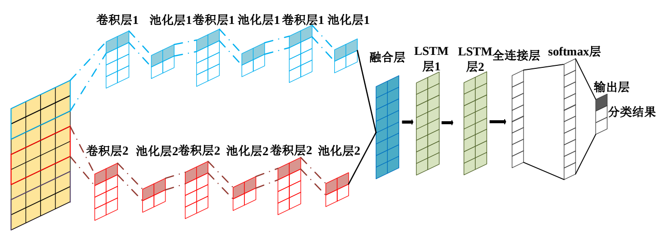


图3-1 PCNN-LSTM模型结构

各神经网络层参数如表3-1所示：

表 4-1 PCNN-LSTM 各层网络参数

网络层	卷积核个数(神经元个数)	卷积核(池化核)大小	步长	输出尺寸
卷积层 1-1	32	128×1	8	485×32
卷积层 1-2	32	64×1	8	473×32
池化层 1-1	-	8×1	4	120×32
Reshape1 -1	-	-	-	3840×1
池化层 1-2	-	8×1	4	117×32
Reshape1 -2	-	-	-	3744×1
卷积层 2-1	32	128×1	8	485×32
卷积层 2-2	32	64×1	8	473×32
池化层 2-1	-	8×1	4	120×32
Reshape2 -1	-	-	-	3840×1
池化层 2-2	-	4×1	2	234×32
Reshape2 -2	-	-	-	7488×1
卷积层 3-1	16	16×1	4	933×16
卷积层 3-2	16	32×1	8	933×16
池化层 3-1	-	2×1	2	466×16
Reshape3 -1	-	-	-	7456×1
池化层 3-2	-	2×1	2	933×16
Reshape3 -2	-	-	-	14928×1
融合层	-	-	-	933×32
LSTM 层 1	-	-	-	933×16
LSTM 层 2	-	-	-	933×16
全连接层	60	-	-	60×1
softmax 层	5	-	-	5×1

PCNN-LSTM模型的运行流程如下：

（1）以7:3的比例将降噪降维后的故障数据集划分为训练集和测试集，其中训练集用以训练PCNN-LSTM，测试集用以验证模型的故障分类精度。

（2）设置模型的初始学习率、梯度阈值等参数。

（3）以损失函数为指标，通过迭代训练PCNN-LSTM模型。

（4）通过测试集验证PCNN-LSTM的异步电机故障分类准确率。

4 实验过程及分析

4.1样本集的构造

本课题采用渥太华大学于2023年12月16日发布的异步电机故障数据集，异步电机型号为D396 Marathon。本数据集包含8种异步电机健康状态，每种健康状态包含4种恒速和4种不同变速、有负载和无负载共16种工况下的电机健康状态数据集。每组数据包含3列加速度数据，1列声学数据，1列温度数据，每列数据包含420000个采样点，即每种异步电机健康状态下分别包含33600000个数据点。每组数据的采样时间为10秒，采样频率为42KHz。

由于定子、转子和轴承是异步电机中最容易出现故障的3类部件，因此本课题选择健康、定子绕组故障、转子弯曲、转子条损坏、轴承故障五类健康状态进行诊断，各故障状态均包含33600000个数据点。根

据文献查阅和实验结果，各组数据中的声学数据和温度数据的相关干扰源过多，受外界噪声干扰过于严重，数据质量较差，难以实现较高的异步电机故障分类准确度。因此本文仅采用每组数据中的三列振动数据进行故障诊断，则每种故障状态包含20160000个数据点。

4.2特征数据集的建立

（1）基于长短时记忆神经网络的降噪实验

本文采用传统的VMD降噪和LSTM降噪与本文提出的STFT-LSTM降噪方法对比，得到的实验结果如图4-1所示，SNR、RMSE 如表4-1所示。

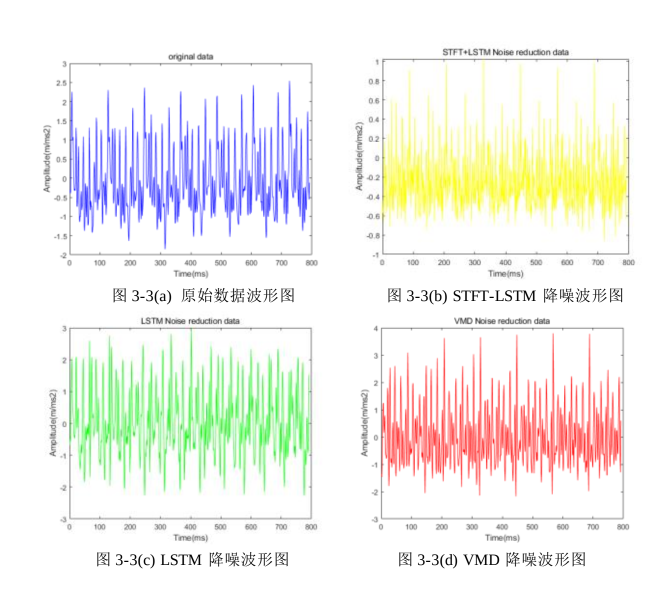


图 3-3(a) 原始数据波形图　图 3-3(b) STFT-LSTM 降噪波形图

图 3-3(c) LSTM 降噪波形图　图 3-3(d) VMD 降噪波形图

表4-1 三种方法降噪后的SNR和RMSE值

	LSTM	STFT-LSTM	VMD
SNR	8.37	10.36	7.95
RMSE	0.042	0.028	0.039

通过对比可知，STFT-LSTM方法的降噪效果与LSTM方法、VMD方法相比有一定程度的提升，信噪比和均方根误差均有改善。STFT-LSTM降噪方法显著降低了原始故障数据集中的噪声，减小了噪声对振动信号的干扰，为提高分类精度打下了坚实基础。

（2）基于平均影响值算法的特征维度降维研究

首先计算异步电机故障数据集的均值、方差、峰值、峭度、有效值、峰值因子、脉冲因子、波形因子、裕度因子9个特征变量，9个特征向量可组成特征变量矩阵。随后通过MIV算法计算每个特征变量的特征重要程度和特征贡献率，将9个特征变量按重要程度从高到低排序。最后，将各特征变量的重要程度归一化，设置贡献率的最大值为1，由高贡献度开始计算特征变量的累计贡献率。特征变量重要程度如图4-2所示，特征变量累计贡献率如图4-3所示：

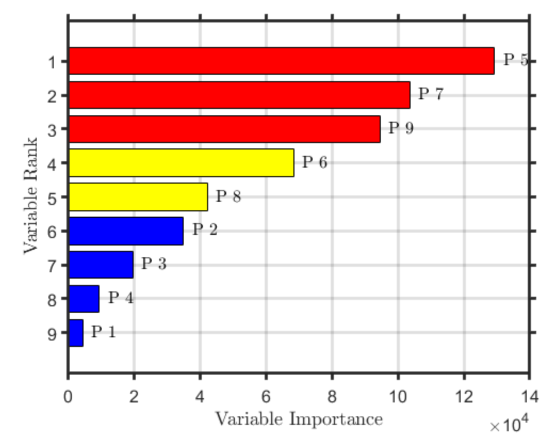


图 4-2 特征变量重要程度图

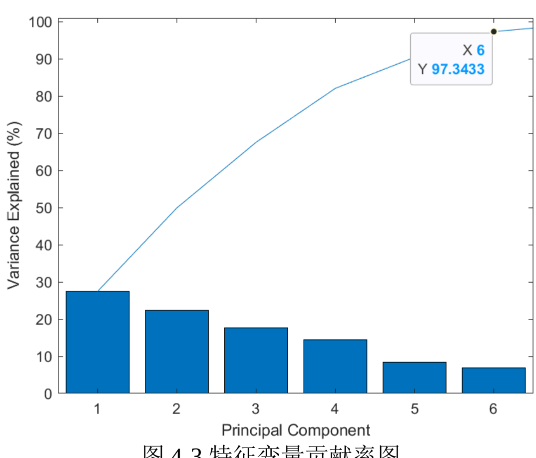


图 4-3 特征变量贡献率图

由图可知，前6个特征变量的累计贡献率达到97.34%，能够充分表征异步电机故障数据的特征信息，因此选取前6个变量作为异步电机故障分类模型的输入数据。前6个特征变量分别是有效值、脉冲因子、裕度因子、峰值因子、波形因子、方差。

4.3故障诊断结果

（1）PCNN-LSTM模型诊断结果

本文提出的PCNN-LSTM模型中的CNN层选用Sgdm优化器，进行30轮训练，初始学习速率设为0.02，每当迭代20轮验证一次评估指标。LSTM层选用Sgdm优化器，进行60轮迭代，初始学习速率设为0.05，梯度阈值设为1，dropout比率设为0.2。

将经过降噪及降维预处理后的故障数据集输入PCNN-LSTM模型进行训练，将故障数据集按7:3的比例划分为训练集与测试集，使用测试集数据对训练完成的PCNN-LSTM模型进行验证，验证结果的混淆矩阵如图4-4所示

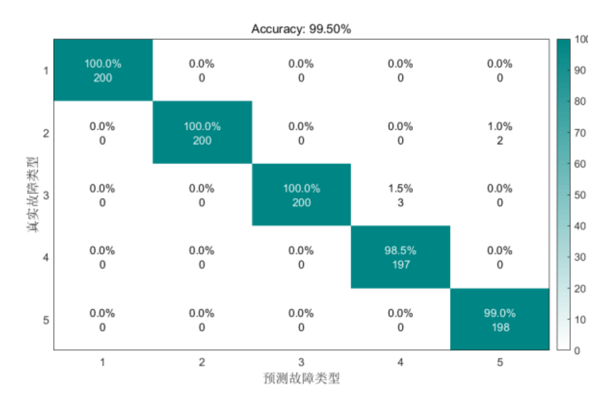


图 4-4 分类结果混淆矩阵

其中故障类型1表示健康状态，类型2表示定子绕组故障，类型3表示转子弯曲故障，类型4表示转子条损坏故障，类型5表示轴承故障。

根据混淆矩阵可知，总的故障分类准确率为99.5%。不存在将故障状态分类为正常状态的情况，定子绕组故障和轴承损坏的分类准确率均为100%，只有转子弯曲、转子条损坏两类故障分别存在1.5%和1%的错误分类样本。

为了更加直观地反映PCNN-LSTM模型的故障分类能力，利用t分布随机近邻嵌入(t-sne)对分类结果做可视化处理，处理结果如图4-5所示：

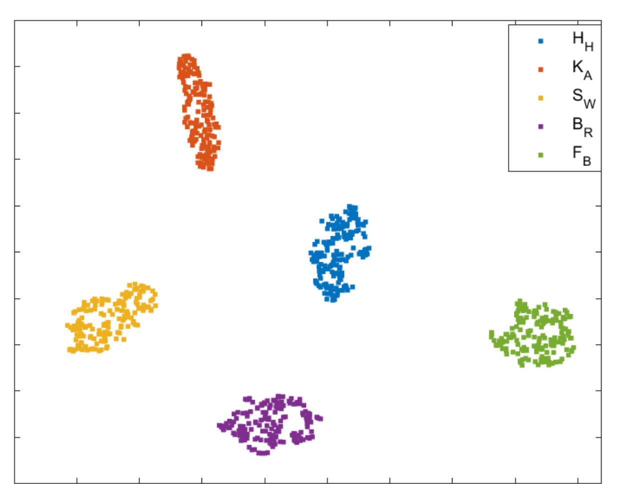


图 4-14 故障分类结果的 t-sne 可视化效果图

由图可知，不同健康状态的异步电机故障数据被明显区分开，说明本文提出的PCNN-LSTM模型对异步电机的不同故障有良好的分类效果。

(2)各种模型结果对比

为了验证本文提出的PCNN-LSTM模型在异步电机故障分类方面的效果，将PCNN-LSTM与卷积长短时记忆神经网络(CNN-LSTM)、卷积支持向量机(CNN-SVM)、极限学习机(ELM)进行对比实验，实验结果如表4-2所示。对比各模型的实验结果可知，本文所采用的PCNN-LSTM模型在故障分类准确率和损失值上均优于其他模型，说明本模型在异步电机故障诊断领域具有显著的优越性。

表4-2 各模型的故障分类准确率

模型	准确率
PCNN-LSTM	99.5%
CNN-LSTM	99.1%
ELM	95.5%
CNN-SVM	98.3%

5 结论

本文针对复杂控制系统进行故障预测，以异步电机系统为研究对象。为了改善降噪效果，提出STFT-LSTM模型，与其他典型降噪方法对比，该方法降噪具有良好效果。为了去除冗余信息，减少了故障诊断所需的时间，采用MIV算法进行数据降维，利用MIV方法计算各特征变量的重要程度，进而计算归一化的累计贡献率，提高了数据质量。为了增强故障分类的性能，本文提出了PCNN-LSTM故障分类方法，将双通道CNN的特征提取能力和LSTM的时序信息记忆能力相结合，根据对比试验结果，相比与其他故障预测方法，本文提出的PCNN-LSTM模型准确率更高。

参考文献

[1] 杨洋. 基于EMD和小波分析的减速齿轮箱故障诊断研究[D]. 西南交通大学, 2021.

[2] Zhao Y, Li Y, Dong X, et al. Low-frequency noise suppression method based on improved DnCNN in desert seismic data[J]. IEEE Geoscience and Remote Sensing Letters, 2018, 16(5): 811-815.

[3] Sun H, Zhao S. Fault diagnosis for bearing based on 1DCNN and LSTM[J]. Shock and Vibration, 2021, 2021: 1-17.

[4] Chua L O, Roska T. The CNN paradigm[J]. IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications, 1993, 40(3): 147-156.

[5] Torrence C, Compo G P. A practical guide to wavelet analysis[J]. Bulletin of the American Meteorological society, 1998, 79(1): 61-78.

[6] 熊林林, 宫翔, 梁勇, 等. 基于VDM和小波阈值的语音降噪方法研究[J].电子质量, 2023, (05): 68-72.

[7] Chauhan V K, Dahiya K, Sharma A. Problem formulations and solvers in linear SVM: a review[J]. Artificial Intelligence Review, 2019, 52: 803-855.